

-ARAŞTIRMA MAKALESİ-

YAPAY ZEKA TEKNİKLERİ İLE KRİPTO PARA DEĞERİ TAHMİNİ*

Mehlika KOCABAŞ AKAY¹

Dr. Öğr. Üyesi

Kocaeli Üniversitesi, Mühendislik Fakültesi

E-mail: mehlika.kocabas@kocaeli.edu.tr

ORCID ID: 0000-0003-0564-4625

Fatma CANİK

Endüstri Mühendisi

Kocaeli Üniversitesi, Mühendislik Fakültesi

E-mail: fatmaacanik@gmail.com

ORCID ID: 0000-0002-7642-6097

Ceren YEŞİLYURT

Endüstri Mühendisi

Kocaeli Üniversitesi, Mühendislik Fakültesi

E-mail: cerenyesityurt99@gmail.com

ORCID ID: 0000-0003-0579-0470

Meral ŞAHİN GÜNKUT

Okul Müdürü

Derince Kız Anadolu İmam Hatip Lisesi

E-mail: meralmary@gmail.com

ORCID ID: 0000-0001-7023-0803

* Bu çalışmada bilimsel araştırma ve yayın etiği ilkelerine uyulmuştur.

¹ **Sorumlu Yazar:** mehlika.kocabas@kocaeli.edu.tr

Atıf (APA): Kocabaş Akay, M., Canik, F., Yeşilyurt, C. & Şahin Günkut, M., (2022), Yapay Zeka Teknikleri ile Kripto Para Değeri Tahmini, Ekonomi Bilimleri Dergisi, 14 (1): 42-71., <https://doi.org/10.55827/ebd.1060983>

Lisans: Bu makalenin kullanım izni Creative Commons Attribution-NoCommercial-NoDerivs 3.0 Unported (CC BY-NC-ND3.0) lisansı aracılığıyla bedelsiz sunulmaktadır.

Öz

Para ve diğer ödeme araçları bugüne kadar birçok değişikliğe uğramıştır. Teknolojik gelişmelerin beraberinde getirdiği yaygın internet kullanımı ile, bugün ödeme araçlarına alternatif olarak kripto paralar tercih edilmektedir. Bu çalışmanın amacı, kripto para birimlerinin gelecek fiyat tahminlemesini gerçeğe en yakın şekilde yapacak yöntemi araştırmaktır. Böylece ödeme araçlarında meydana gelen gelişmelere katkıda bulunarak, piyasa analizlerinde kolaylık sağlanacaktır. Çalışmanın yapılması sırasında yapay sinir ağları (YSA) ve uzun kısa süreli bellek (LSTM) yapay zeka yöntemleri kullanılmıştır. Çalışmada kullanılan iki yöntemin de sonuçları ayrı ayrı değerlendirilerek, üretilen sonuçlar doğrultusunda performans kıyaslaması yapılmıştır. Çalışmada tercih edilen üç adet kripto para birimi XRP, BNB ve ETH olarak belirlenmiştir. Bu kapsamda incelenecek veriler yahoo web adresinden çekilmiştir ve veri seti 01.01.2020-07.05.2021 tarihler arasında kapsamaktadır. Yapılan kıyaslama analizleri sonucunda yapay sinir ağları aracılığı ile gerçekleştirilmiş olan matlab uygulamasında tahminleme sonuçlarının başarılı ve anlamlı olduğu ortaya çıkmıştır.

Anahtar Kelimeler: Kripto Para, Yapay Sinir Ağı, LSTM, Ödeme araçları, Fiyat Tahmini

Alan Tanımı: Ekonomi, İstatistik

CRYPTO VALUE FORECASTING WITH ARTIFICIAL INTELLIGENCE TECHNIQUES**Abstract**

Money and other payment instruments have undergone many changes until today. With the widespread use of the internet brought about by technological developments, today cryptocurrencies are preferred as an alternative to payment tools. The purpose of this study is to investigate the method that will make the future price prediction of cryptocurrencies as close to the truth. Thus, market analysis will be facilitated by contributing to the developments in payment instruments. During the study, artificial neural networks (ANN) and long short-term memory (LSTM) artificial intelligence methods were used. The results of both methods used in the study were evaluated separately and a performance comparison was made in line with the results produced. The three preferred cryptocurrencies in the study were determined as XRP, BNB and ETH. The data to be analyzed in this context was taken from the yahoo website and the data set covers the dates between 01.01.2020-07.05.2021. As a result of the comparison

analysis, it has been revealed that the estimation results are successful and meaningful in the matlab application performed through artificial neural networks.

Key Words: *Crypto Money, Artificial Neural Network, LSTM, Payment Means, Price Prediction*

JEL Codes: *Economics, Statistics.*

1.GİRİŞ

Geçmişten bu yana bilim ve teknoloji alanındaki gelişmelerin hızlı bir biçimde ilerlemesi ekonomide ve finansal alanlarda yeni arayışlar yaratmaktadır. Dünyadaki ekonomik yapıları ve finans piyasalarını etki altına alan gelişmeler, mali araçlara ve yatırım araçlarına da yön vermektedir. Ekonomik alandaki teknolojinin ilerlemesi ilk olarak ödeme transfer sistemlerinde kendini göstermiştir. Değişen sosyal hayatın etkisiyle ihtiyaçlar da değişmiştir. Bununla beraber ödeme yöntemlerinden havale ya da dijital fon transferi gibi işlemleri gerçekleştirecek yeni yollar bulunmuştur.

Dünya 2008 yılında tamamen dijital teknoloji temelli yepyeni bir para kavramı ile tanışmıştır. Kendilerini “Kripto para” olarak tanımlayan bu yeni tür paranın ilk örneği Satoshi Nakamoto kod adıyla ortaya çıkan kişi veya kurum tarafından geliştirilip piyasaya sürülen Bitcoin olmuştur. Bu para Satoshi Nakamoto (Samsung, Toshiba, Nakamichi, Motorola2) tarafından geliştirildiği söylenen ancak anonim bir yapının arkasına gizlenen açık kaynak kodlu bir yazılımdır. Ve o günden itibaren dünya kripto paraların engellenemez yükselişini izlemektedir. Bugün piyasalarda 10.524 adet kripto para bulunurken bu sayı inanılmaz bir hızla sürekli olarak artmaktadır (Coin Market Cap, 2021).

Bitcoin ile adını duyurmaya başlayan bu sanal paralar, finans alanında hatırı sayılır bir yer edinmeyi başarmıştır. Tanım olarak para üç temel nitelikten (değer saklama aracı, hesap birimi, değişim aracı) meydana gelmektedir. Ancak kripto para için bu tanım tamamıyla farklıdır. Kripto para birimleri fiziki paralar gibi yatırım ve tasarruf aracı olarak kullanılsalar da yasal düzenlemelere ve merkezi bir otoriteye bağlı olmamalarından ötürü geleneksel paralardan ayrılmaktadırlar.

Dijital ekonominin yarattığı bir ürün olarak kripto paralar, bankacılık işlemlerine ihtiyaç duyulmadan yalnızca internet ile işlem yapabilme özelliğine sahiptirler. Blok zincir teknolojisi ile gizliliği sağlaması en büyük avantajlarından olan kripto paralar yatırımcılar tarafından yatırım aracı olarak kullanılmaktadır. Kitlelerce benimsenen ve kabul gören kripto paralar medyanın da etkisiyle yaygınlaşmıştır. Öte yandan giderek popüleritesi artan bu sanal paralar birtakım olumsuz etkilere

de sebep olabilmektedirler. Yasal düzenlemelere tabi olmaması ve merkezi bir otoriteye bağılı olmaması sebebiyle kripto piyasası yasadışı faaliyetler için kullanılabilen ve siber güvenlik problemleri de yaşanabilmektedir.

Teknolojinin vazgeçilmez etkilerini gördüğümüz finans sektöründe kripto paraların geleceğin mali altyapısını oluşturabileceği ön görülmektedir. Fiziki paralarla rekabet içerisinde olan kripto paralar dünyanın en değerli para birimleri arasına girmiştir.

Bu çalışmanın amacı kripto para birimlerinin değerlerini gerçeğe en yakın şekilde tahmin edebilen metodu ortaya koymaktır. Bu çalışmada popüler olan kripto paralardan temsili olarak seçilen üç tanesi üzerinde yapay zekâ programları kullanılmış ve tahminleme metotları ile çalışma yapılmıştır. Çalışma kapsamında Ethereum (ETH), Binance (BNB) ve Ripple (XRP) kripto para birimleri kullanılmıştır. Bu çalışmada kullanılan veriler, kripto para birimlerinin günlük kapanış fiyatları üzerinden istatiki değerleri sağlayan internet siteleri üzerinden alınarak nitelikli bilgiler olarak sunulmuştur. Bu üç adet kripto paranın yapay sinir ağı ve LSTM metodu ile fiyat tahmin modellemesi yapılmıştır. Kurulan modellerin uygunluğu anlaşılıp ön raporlama performansları ölçüldükten sonra tahmin adımına geçilmiştir. Tahmin adımından sonra kasit model kurma aşamasında kullanılmayan veriler öngörülme çalışılmıştır. İki model de çalıştırıldıktan ve hata oranları tespit edildikten sonra işlem yapılan üç kripto para için de bu katsayılar karşılaştırılarak en az hataya sahip olan model o kripto için en uygun model olarak belirlenmiştir. Kripto paralar için seçilebilecek en iyi tahmini yapan uygulamayı bulmak adına seçilen iki programın hata payları kıyaslanmıştır. Böylece bu çalışmadan çıkan sonuçlar ile fiyat değerleri üzerinde yapılan analizler daha doğru ve daha kolay sonuçlanabilecektir.

Bu çalışma, literatürdeki diğer çalışmalardan farklı olarak tahminleme yaparken iki farklı yöntemi kıyaslayarak gelecek çalışmalar için kullanılacak daha doğru sonuç veren yöntem önerisinde bulunmak için hazırlanmıştır. Bu kapsamda çalışma içerisinde yapay sinir ağı ve LSTM metotları kullanılarak, en sık kullanılan kripto paralar ile tahminleme yapılmıştır.

2.LİTERATÜR TARAMASI

2.1. Kripto Paraların Tanımı

İngilizce kökenli "crypto" ve "currency/money" kelimeleri yan yana getirilerek oluşturulan Kripto Para "Şifreli Para", "Gizli Para" anlamına gelmektedir. Belirli bir sisteme göre şifreli anahtarlar ile alım-satım ve transfer işlemleri gerçekleştirilebildiği için kripto para ismini almıştır.

Kripto para elektronik paradır. Ödeme yöntemlerini incelendiğinde geleneksel ödemelere göre daha hızlı ve bankalar ya da devletler tarafından yönetilmemektedir. Bu yüzden popülerliği hızlıca yükselmektedir. 2014 yılında Kanada Merkez Bankası kripto para üzerine inceleme yapmış ve merkezi olmayan sanal para olarak tanımlamıştır. Elektronik para olarak nitelendirilen bu tanım, diğer para birimlerine kıyasla basımı olmayan ve ihraç edenin kim olduğu bilinmeyen para birimidir.

Kripto paraların ortaya çıkışında 2008 finansal krizinin etkili olduğu düşünülmektedir. Küresel krizden sonra ilk kripto para birimi Bitcoin Satoshi Nakamoto mahlaslı kişi veya kurum tarafından yayınlanan Bitcoin: A Peer-to-Peer Electronic Cash System başlıklı makale çalışmasıyla ortaya atılmış ve kripto paraların dayandığı teknik altyapı geliştirilmiştir (Nakamoto, 2008).

2009 yılında en popüler olan kripto Bitcoin ortaya çıkmıştır. Elektronik para yerine piyasada elektronik emtia olarak tanımlanmaktadır. Bunun sebebi ise kripto paraların değeri sadece sayısal olması ve emtia gibi değerlendirilip sınırlı olmasıdır (Ateş,2016: 349-366).

Kripto para birimleri, şifrelenmiş Blokzinciri olarak adlandırılan bir yapı kullanılarak sunulan, internet temelli elektronik ortamlarda işlem gören, fiziksel varlığı olmayan, merkezi bulunmayan, devlet gibi bir otorite tarafından kontrol altına girmeyen, taraflar arası hızlı, düşük maliyetli ve güvenli bir para transferi sağlayan sanal para birimleri olarak tanımlanmaktadır (Özkul & Baş, 2020: 60).

Kripto paraların birçoğunun merkezi bulunmamaktadır. Bu teknolojinin kontrolü Blokzincir (*BlockChain*) adı verilen işlem veri tabanları tarafından sağlanmaktadır. Kripto paraların üretilmesi madenci (*Miner*) denilen kişiler tarafından yapılmaktadır. Üretilmesi işlemine de madencilik (*mining*) denilmektedir. Bu üretim aşamasında gelişmiş işlemcili (*CPU*) bilgisayarlar, ekran kartları (*GPU*) ve diğer özel üretilen makineler (*ASIC*) kullanılmaktadır (Kaplanhan, 2018)

Blok zincirinin tarihi bölümünde bahsedilen bilgilerden yola çıkarak blok zincirinin geçmişini en az 25-30 yıl öncesine dayandırabiliriz. İlk kripto paranın ortaya çıkmasına kadar geçen süre zarfında blok zincirinin farklı alanlarda kullanımı söz konusu olmuştur. Blok zinciri sadece para ve finans alanında değil merkezi bir şekilde veri tutulması gereken her sistemde kullanılabilir.

İlk kripto para Bitcoin'in tüm transfer işlemlerini sanal ortamda herkese açık bir şekilde, işlem sırasına göre sıraladığı sistem olan blok zinciriyle ilk defa kripto paralar ile blok zincirinin yolları birleşmiştir. Akabinde bilindiği üzere pek çok

kripto para kullanıma sunulmuştur. Bu kripto paraların neredeyse tamamı verilerini blok zinciri yöntemiyle tutmaktadır. Ethereum gibi yakın zamanlarda kullanıma açılan gerek işlemleri blok zincire daha hızlı kaydedebilmesiyle gerek daha farklı ve kapsamlı hizmetler sunmasıyla gerekse blok içinde daha farklı ve fazla bilgi tutması yönüyle kısa zamanda ismini duyurmuş blok zincirini geliştirerek kullanan kripto paralar da vardır.

Blok-Zinciri teknolojinin yanında kripto paralarda rağbet gören en büyük unsuru fiyat dalgalanmasının yüksek olmasına rağmen uzun vadeli olarak artış trendi gözlemlenmektedir. Reel piyasalarda kullanımı yaygınlık göstermemesine rağmen işlem hacmi 2017 yılının son çeyreğinde büyük artış gözlemlenmiştir. Bunun yanı sıra artan taleple beraber astronomik artışlara neden olmuştur. Birçok yatırımcı bu sebeple kısa ve uzun vadede kripto para ticaretine ilgi duymuştur. Aşağıdaki Tablo 1’de 2013 yılından sonra altın, Bitcoin ve dövize yapılmış olan yatırımın nominal kazancını göstermektedir. Bitcoin’in girdiği süreçten sonra uzun vadede incelendiğinde diğer yatırım araçlarına oranla kıyaslanmayacak kadar kazanç sağlamıştır (Dağlı, 2019:40-49).

Tablo 1. Altın, USD, EURO, Bitcoin kazançlarının karşılaştırması (2013-2018) (Dağlı, 2019:40-49)

2013 YILI SONRASI 1000₺ NE KADAR OLDU?				
YIL	ALTIN	USD	EURO	BİTCOİN
2014	1,137.60 ₺	1,211.11 ₺	1,262.71 ₺	7,961.04 ₺
2015	1,059.40 ₺	1,305.56 ₺	1,199.15 ₺	3,546.76 ₺
2016	1,194.61 ₺	1,622.22 ₺	1,351.69 ₺	5,973.66 ₺
2017	1,566.47 ₺	1,966.67 ₺	1,576.27 ₺	16,354.43 ₺
2018	1,902.04 ₺	2,094.44 ₺	1,927.97 ₺	246,886.67 ₺
Kazanç Oranı	90%	109%	93%	24588%

Kripto para, devlet otoritelerinden veya aracı kurumlardan tamamen bağımsız, internet üzerinden işlem gören sanal paraların genel adıdır. Çevrim içi ödeme, internet oyunlarında değişim aracı olarak kullanma gibi farklı amaçlara hizmet etme niyetiyle oluşturulan birçok kripto para çeşidi vardır. Hatta kullanılan teknoloji açısından da farklılıkları vardır. 20 Nisan 2018 tarihiyle piyasada toplam 1584 kripto para bulunmaktadır.

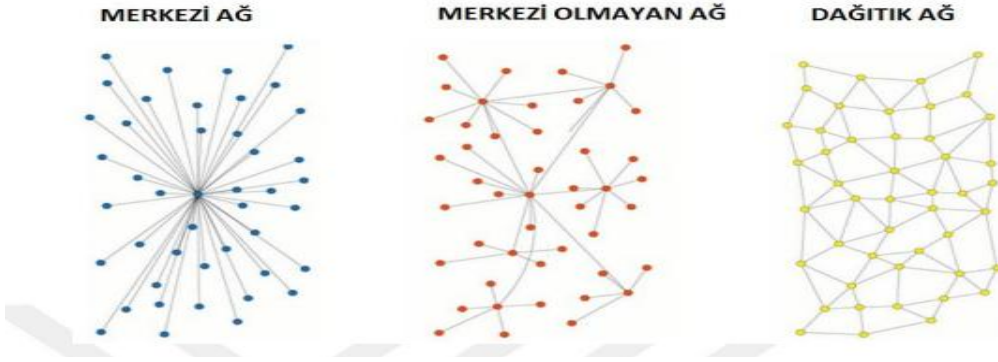
2.2. Kripto Paraların Yapısı

Kripto para arz ve talep dengesiyle oluşmakta ve her bir paranın belirli bir değeri vardır. Kripto paranın ayrıca fiyatlarının kontrol edilebilmesi adına miktarları belli seviyede sınırlandırılmıştır. Örneğin 21 milyon adet ile Bitcoin sınırlandırılırken Ethereum ise 72 milyon adetle sınırlandırma gerçekleştirilmiştir. Dolaşım olarak incelendiğinde bu miktar daha düşüktür. Kripto para yapısında çağın teknolojisi olarak adlandırılan en önemli yapı Blockchain yapısıdır. Bu kelimenin Türkçe anlamı blok zinciridir. Bu blok zinciri herhangi bir üçüncü kişiye gerek olmadan değer transferi gerçekleştiren ve yapılan bu işlemleri kayıt altına alan defterdir.

Sayısal değerler şekillenen bloklar zincirler ile birbirlerine bağlıdır. Bağlı olunan bloklar değiştirilemez ve işlemleri hep üstüne kaydederek ilerleyip işlemcide saklanır. Blok zinciri, yapılan tüm işlemlerin dünya çapında herkese ulaşabilmesini ve bulunan konumdan yönetilebilmektedir.

Veri farklı yöntemler ile depolanabilmektedir. Bu yöntemler sırasıyla dağınık, merkezi ve çok merkezli ağ yapılarıdır. Şekil 1.' de yapıları gösterilmektedir.

Şekil 1. Merkezi, çok merkezli ve dağınık ağ (Atlan,2019)




Merkezi: Mevcut olan verilerin tek merkezi alanda bulunmasıdır. Merkez verileri silme ve değiştirebilmektedir. Tek merkezli olması yöntemini kolaylaştırmaktadır. Ama herhangi bir merkezde oluşan hata durumu tüm herkesi etkileyebilir.

Çok merkezli: Birçok merkezden oluşmakta ve tek merkezden yönetilmemektedir. Tüm kullanıcılar bağlantıyı yönetebilmek için birbiriyle iletişim kurmalıdır.

Dağınık: Ortak hedef için her işlem etkileşim halindedir. Merkez kısmından geçmeden birbiri ile etkileşim sağlayabilirler. Kontrol ve güvenlik tüm ağ üzerine dağılabilmektedir.

Geleneksel işlenen veri tabanları ise kopya mantığıyla çoğalmaktadır. Ana oluşan kopyayı tek başına güncellebilir. Bu veri tabanlarının işlem kontrolü ve veri tabanı üzerinde çalışması daha zordur. Şekil 2’de geleneksel ve blok zinciri veri tabanı gösterilmiştir.

Şekil 2. Geleneksel ve blok zinciri veri tabanı (Ömrüzun & Saldanlı,2019)



Blok zincir teknolojisinin ve kripto para kullanımının avantajlarını şu şekilde sıralamak mümkündür:

- Finans ve teknolojinin ayrılmaz bir hal alması ve birlikte gelişimi nedeniyle EFT veya SWIFT gibi klasik para transfer yöntemlerinin maliyetleri de yükselmektedir. Kripto teknolojiler de ise daha ucuz finansal hizmetler alınabilmektedir.
- Banka ve diğer finansal kuruluşlara bağımlı olmadan özgürce herkesin cep telefonundan temel bankacılık hizmetlerine erişimi sağlanmaktadır.
- Hizmetler geleneksel bankacılık hizmetlerinden daha hızlı gerçekleşmektedir.
- Blokzincir sisteminin özelliğinden kaynaklanarak kişisel bilgilerin gizliliğine önem verilmektedir. Kayıtların sistemi kullanan tüm üyelerde mevcut olması sebebiyle hesaplarda değişiklik veya hesaplara saldırı yapılamaması, dolandırıcılık ihtimalinin düşük olması (Kaya, Kripto Para Birimleri ve Fıkhi Açından Değerlendirilmesi, 2018).
- Devletin süreçte yer almaması nedeniyle işlemler sonucunda vergi gibi kanuni yaptırımlar yoktur.

Blokzincir teknolojisinin ve kripto para kullanımının dezavantajlarını ise şu şekilde sıralamak mümkündür:

- Yazılımların güvenliği konusu en büyük risklerdendir. Veri ihlalinin önüne geçilmesi zor gözükmektedir.
- Blokzincir teknolojisinin henüz detaylı olarak bilinmemesi nedeniyle potansiyel kullanıcılarda tedirginliğe sebep olmaktadır
- Hukuki bir zemini olmayan kripto paraların risk olasılığı ve fiyat değişkenliği yüksektir. Alış ve satış fiyatları arasında beklenmedik yükselişler ve düşüşler olabilmektedir.
- Kripto para üretiminin yüksek miktarda elektriğe ihtiyaç duyması ve bununla birlikte kripto para çeşitliliğinin sürekli artmakta olması
- Kripto paralar genel olarak devletlerin veya herhangi bir bağımsız denetim kuruluşunun kontrolünde değildir. Gözetime tabii olmayan kripto paraların (kara para aklama, yasa dışı örgütler tarafından kullanılma, uyuşturucu ve silah kaçakçılığı gibi) yasadışı finansal faaliyetlerde kullanılması mümkündür. Bu açık çok önemli bir tehlike olarak karşımıza çıkmaktadır.
- Bitcoin sisteminde olduğu gibi para arzı miktarı kısıtlı olması nedeniyle para darlığı olarak ifade edilen deflasyona maruz kalınması mümkündür.
- Bireyler için avantaj olarak ifade edilen kaydının yapılamaması ve vergi alınmaması devletler adına bir dezavantaj olarak değerlendirilebilir.

Global finans piyasası e-ticaret birlikte gelişmekte ve birtakım fiziksel sınırlandırılmalarından kurtulmaktadır. Bu sayede ise kullanıcı sayısının artması amaç edinilmiştir. Kripto paraların da bu sisteme dahil olduğu göz önünde bulundurulduğunda, gelişen dijital ödeme sistemlerinin ekonomiye olan etkisi; para politikası, pazarlama yönetimi ve finansal yönetim gibi konularda anlaşılmaktadır. Bu konulara dahil olan finansal araçların da verimli ve düşük maliyetler ile işlevlerini yerine getirmeleri nakit yönetiminde pozitif bir etki bırakmaktadır. Aynı zamanda likidite ve finansal riski düşürmesi açısından da bankacılık, perakendecilik ve sigortacılık gibi sektörlerde alışveriş oranında olumlu yönde artış göstereceği düşünülmektedir.

Plohmann ve Padilla, Bitcoin madenciliğini farklı bir bakış açısından incelemişlerdir. Yazılımlar ile Bitcoin madenciliğinin nasıl yapılabileceği hakkında bilgi sağlamışlardır.

Atik Bitcoin'in döviz kurları üzerindeki etkisi hakkında bir çalışma yapmıştır. 2009- 2015 tarihleri arasındaki günlük fiyat verilerini kullanmıştır. Bu verilerden

elde ettiği sonuçlardan; Japon Yen'i ve Bitcoin arasındaki korelasyondan ötürü birbirlerini etkiledikleri kanısına varmış ve Japon Yeni tarafından Bitcoin'e tek yönlü bir nedensellik ilişkisinin olduğu sonucunu ortaya koymuştur.

Farklı kripto para borsaları üzerinde yaptığı çalışmada fiyat oluşumunun hızlı tepki verebilme kabiliyetini ölçmüştür. Yüksek işlem hacimi kripto para borsalarının fiyat oluşumunda pazarda yapıcı rol oynadığını daha küçük çaplı borsaların ise pazarda izleyici olarak bulunduğunu ortaya koymuştur (Karakoyun,2018).

Hukuki açıdan Bitcoin'in incelendiği çalışmada ise kripto paraların devletlerce yasal olduğu tanımlanınca fiyatlardaki volalitenin azalacağını bu sebeple ise kripto paraların kısa sürede bir varlık sınıfı haline geleceği belirtilmiştir (Ömrüz ve Saldan,2019)

Karaoğlan vd. (2018:15)'nin çalışması iki asıl amaç için yapılmıştır. Bunlardan ilki, Türk toplumundaki kripto para farkındalığını ve bu piyasaya karşı tutumunu ölçmek iken, bir diğer amaç ise kripto para piyasasını kullanan Türk işletmelerinin motivasyonlarını araştırmaktır. Elde edilen sonuçlara istinaden iş dünyası toplumunun üçlü ölçeği için türlü çıkarım ve öneriler yapılmıştır (Temür,2019)

Shahzad vd.(2019) makalesinde, Bitcoin'in borsa yatırım aracı olarak güvenli bir seçenek olup olmadığı ve bu şekildeki bir mülkün emtia endekslerine benzer olup olmadığı konusuna değinmiştir.

Hayes(2017:1308) çalışmasında, kripto para birimlerinin değerlerini etkileyen faktörleri belirlemeyi hedeflemiştir. Özellikle Bitcoin'in popülerliğinin giderek artması sebebiyle değerini oluşturan faktörleri belirlemenin önemi de artmıştır. Bu makalesi kapsamında en yaygın olan 66 kripto para birimini inceleyen kesitsel ampirik verileri kullanarak bu sanal paraların değerlerinin üç ana faktörüne dikkat çeken bir regreesyon analizi modeli ortaya koymuştur (Karahan,2015).

Ciaian ve Rajcaniova (2016:883) çalışmasında, Bitcoin'in global düzeyde bir para birimi haline gelmesini kolaylaştırabilecek özelliklerini ve bunun yanısıra bir değişim birimi, hesap aracı olarak kullanımını engelleyebilecek özelliklerini tanımlamış ve bunları analiz etmiştir. Standart para birimleri ile Bitcoin'i karşılaştırmıştır. Analizleri doğrultusunda en belirgin sonuç standart para birimleri karşısında Bitcoin'in aşırı fiyat dalgalanmalarıdır. Bu fiyatlardaki dalgalanma durumlarının sebeplerini algılayabilmek amacıyla Bitcoin değer oluşumundaki belirleyici faktörler ve ekonomik önemi tahmin edilmeye çalışılmıştır. Zaman serileri analizi ile 2009-2014 yılları arasındaki günlük veriler ele alınmıştır. Tahmin sonuçları doğrultusunda makro-finansal gelişmeler uzun dönemde Bitcoin

değerini belirlememektedir. Bulgulara göre Bitcoin değeri spekülâtif yatırımlardan esas olarak kaynaklandığı sürece, Bitcoin'in standart para birimleri ile rakip olamayacağını işaret etmektedir (Ceylan,2019).

Aras 2019 yılında yaptığı çalışmada; Kripto para birimlerini olabildiğince doğru tahmin etmenin yatırımcılar ve karar vericiler için büyük önem taşımakta olduğunu belirtmiştir. Bu çalışma kapsamında en çok kullanılan dört kripto paranın (Bitcoin, Ethereum, Ripple, Litecoin) fiyatları tahmin edilmektedir.

Şahin ve Bağcı 2020'deki çalışmasında, Bitcoin, Ethereum, IOTA ve Ripple gibi farklı özelliklere sahip kripto paraların ileriki dönem değerlerini geçmişte gerçekleşen değerleri kullanarak Deng Ju-Long tarafından 1980'li yıllarda ortaya atılan gri sistem teorisi ile tahmin etmektedir.

Demirel ve Hazar 2021 yılındaki çalışmalarında en büyük işlem hacmine ve en yüksek piyasa değerine sahip Bitcoin (BTC), ethereum (ETH) ve Ripple (XRP) kripto para birimlerinin 2016-2020 yılları arası günlük piyasa değerlerini kullanarak BIST 100 endeksinin hareket yönleri tahmin etmişlerdir.

Sonuç olarak, ulusal ve uluslararası düzeyde yapılan çalışmalar incelendiğinde, kripto para piyasasının henüz yeni bir oluşum olduğu ve gelecekte popülaritesinin giderek artacağını beklediği vurgulanmaktadır. Türkiye'de daha çok teorik çalışmalar yapılmışken, ABD ve Japonya kripto para borsa verileri ile ampirik analizler uluslararası çalışmalarda daha çok yapılmıştır. Çalışmalarda Bitcoin ve diğer kripto paraların işleyişi, itici güçleri ve sektöre olan etkileri incelenmiş ve özetlenmiştir.

3. VERİ SETLERİNİN OLUŞTURULMASI

Veri seti olarak 1 Ocak 2020- 07.05.2021 tarihleri arasındaki BNB, ETH ve XRP kripto para birimlerinin dolar kuru üzerinden günlük değerlerinden faydalanılmıştır. Kripto paraların günlük açılış, en yüksek ve en düşük değerleri girdi olarak alınırken günlük kapanış değerleri çıktı değeri olarak alınmıştır. Çalışma kapsamında, 01.01.2020-31.12.2020 tarihi aralığındaki veri seti program eğitimi için kullanılırken, test için 01.01.2021-07.05.2021 tarihleri arasındaki değerler kullanılmıştır. Her günün kapanış değerleri Microsoft Excel programına girilmiştir. Bu çalışmada dizide yer alan fiyatlar ters sıradadır. Yani son güne ait fiyat dizinin ilk elemanıyken, ilk güne ait fiyat dizinin son elemanıdır. Aşağıdaki Tablo 2'de Excel'e işlenen XRP kripto para birimine ait verilerden bir kesit bulunmaktadır.

Tablo 2. XRP kripto para birimi veri kümesi

Tarih	Açık	Yüksek	Düşük	Kapat	Tarih	Açık	Yüksek	Düşük	Kapat	Tarih	Açık	Yüksek	Düşük	Kapat
31.12.2020	0,2118	0,2276	0,2065	0,2198	30.09.2020	0,2431	0,2431	0,2389	0,2418	2.07.2020	0,1772	0,1783	0,1742	0,1772
30.12.2020	0,2209	0,2354	0,1947	0,2118	29.09.2020	0,2413	0,2466	0,239	0,2432	1.07.2020	0,1758	0,1785	0,1747	0,177
29.12.2020	0,2477	0,2483	0,1748	0,221	28.09.2020	0,2433	0,2477	0,2416	0,2419	30.06.2020	0,1777	0,1784	0,175	0,1759
28.12.2020	0,2834	0,306	0,2394	0,248	27.09.2020	0,2418	0,2444	0,2385	0,2428	29.06.2020	0,1776	0,1796	0,1762	0,178
27.12.2020	0,2948	0,3075	0,2702	0,283	26.09.2020	0,2419	0,2456	0,2387	0,2422	28.06.2020	0,1769	0,1805	0,1752	0,1777
26.12.2020	0,3181	0,3223	0,2872	0,2947	25.09.2020	0,2329	0,2443	0,2303	0,2419	27.06.2020	0,1831	0,1851	0,1745	0,1769
25.12.2020	0,3373	0,3806	0,2852	0,3181	24.09.2020	0,2217	0,2337	0,2203	0,2329	26.06.2020	0,1835	0,1859	0,1799	0,1827
24.12.2020	0,2591	0,3676	0,2437	0,3378	23.09.2020	0,2333	0,235	0,2211	0,2212	25.06.2020	0,1841	0,185	0,181	0,1836
23.12.2020	0,448	0,448	0,2214	0,2586	22.09.2020	0,2318	0,2347	0,2302	0,2334	24.06.2020	0,1887	0,1909	0,183	0,1843
22.12.2020	0,5168	0,5216	0,4106	0,4484	21.09.2020	0,2468	0,2481	0,2305	0,2321	23.06.2020	0,1893	0,19	0,1871	0,1887
21.12.2020	0,556	0,5678	0,5029	0,5169	20.09.2020	0,2517	0,2517	0,2437	0,2467	22.06.2020	0,1857	0,1901	0,1856	0,1893
20.12.2020	0,579	0,5856	0,5385	0,5561	19.09.2020	0,2505	0,2541	0,2484	0,2517	21.06.2020	0,1885	0,1891	0,1855	0,1856
19.12.2020	0,5842	0,602	0,568	0,5792	18.09.2020	0,2523	0,2557	0,2471	0,2507	20.06.2020	0,1868	0,1898	0,1861	0,1885
18.12.2020	0,5767	0,6104	0,5523	0,5843	17.09.2020	0,2477	0,2582	0,2472	0,2522	19.06.2020	0,1909	0,1912	0,1865	0,1868
17.12.2020	0,5685	0,6539	0,5464	0,5767	16.09.2020	0,244	0,251	0,2367	0,2478	18.06.2020	0,1935	0,1935	0,1896	0,191
16.12.2020	0,4697	0,5688	0,442	0,5686	15.09.2020	0,2463	0,2492	0,2434	0,2438	17.06.2020	0,1915	0,1973	0,1903	0,1934
15.12.2020	0,4977	0,5066	0,466	0,4697	14.09.2020	0,2418	0,2498	0,2403	0,2463	16.06.2020	0,1931	0,1933	0,19	0,1913
14.12.2020	0,5116	0,5171	0,4902	0,4977	13.09.2020	0,2478	0,2531	0,2389	0,2418	15.06.2020	0,1916	0,1938	0,1838	0,1931
13.12.2020	0,5067	0,527	0,4873	0,5115	12.09.2020	0,2431	0,2488	0,2418	0,2478	14.06.2020	0,1932	0,1937	0,1911	0,1916

Performansın artırılması ve ağın eğitimi için kullanılan verilerin uygun forma dönüştürülmesi gerekmektedir. Bu işlemler normalizasyon olarak adlandırılmaktadır. Veri setine uygulanan normalizasyon işlemiyle uygun formda veri tabano oluşturulur. Ağın atan değerleri okuması kolaylaştırılır ve bu da metodun performansını artırır. Bu çalışmada normalizasyon Microsoft Excel’de aşağıdaki formül ile yapılmıştır.

$$T_n = 0,8 \frac{T-T_{min}}{T_{max}-T_{min}} + 0,1$$

T : İlk değerleri

T_n : Normalizasyon yapılmış değerleri,

T_{min} : Veri setindeki en küçük değeri

T_{max} : Veri setindeki en büyük değeri ifade etmektedir.

Aşağıdaki tablo 3’de normalize edilmiş XRP veri setinden bir kesit bulunmaktadır.

Tablo 3. XRP Normalizasyonu

Tarih	Açık	Yüksek	Düşük	Kapat	Tarih	Açık	Yüksek	Düşük	Kapat	Tarih	Açık	Yüksek	Düşük	Kapat
31.12.2020	0,20339	0,203945	0,245919	0,2161267	30.09.2020	0	0,614442	0,694372	0,631113	2.07.2020	0,56083	0,544373	0,576073	0,540326
30.12.2020	0,216585	0,213991	0,22708	0,204543	29.09.2020	0,727297	0,662615	0,764618	0,689176	1.07.2020	0,372032	0,507277	0,440052	0,561466
29.12.2020	0,255447	0,230607	0,19531	0,2178643	28.09.2020	0,742668	0,666736	0,804211	0,727548	30.06.2020	0,336795	0,335067	0,392317	0,372941
28.12.2020	0,307214	0,304927	0,298443	0,2569593	27.09.2020	0,706417	0,686057	0,724067	0,742896	29.06.2020	0,322875	0,305571	0,370605	0,337756
27.12.2020	0,323745	0,306859	0,347615	0,307638	26.09.2020	0,779211	0,696748	0,801656	0,706986	28.06.2020	0,334765	0,306601	0,369327	0,323855
26.12.2020	0,357531	0,325922	0,374756	0,3245792	25.09.2020	0,79487	0,712977	0,862642	0,779529	27.06.2020	0,319395	0,302866	0,380982	0,335729
25.12.2020	0,385372	0,401014	0,371563	0,3584615	24.09.2020	0,743683	0,71697	0,844602	0,795457	26.06.2020	0,287203	0,281742	0,344263	0,311258
24.12.2020	0,271978	0,38427	0,305308	0,3869864	23.09.2020	0,704096	0,6782	0,797186	0,744054	25.06.2020	0,285318	0,267058	0,338675	0,288235
23.12.2020	0,545895	0,487828	0,269707	0,2723077	22.09.2020	0,811981	0,726115	0,789044	0,704814	24.06.2020	0,280823	0,267574	0,335322	0,286353
22.12.2020	0,645659	0,582628	0,571762	0,5471312	21.09.2020	0,809806	0,735518	0,9	0,812253	23.06.2020	0,265887	0,253019	0,321912	0,281864
21.12.2020	0,702501	0,642135	0,719118	0,6463167	20.09.2020	0,785155	0,72985	0,871902	0,809937	22.06.2020	0,267917	0,24323	0,319836	0,26695
20.12.2020	0,735853	0,665062	0,775953	0,7030769	19.09.2020	0,859833	0,785622	0,865037	0,785321	21.06.2020	0,264437	0,245291	0,319836	0,268977
19.12.2020	0,743393	0,686186	0,823049	0,7365249	18.09.2020	0,77544	0,776606	0,874775	0,859747	20.06.2020	0,259942	0,251216	0,313291	0,265502
18.12.2020	0,732518	0,697005	0,797984	0,7439095	17.09.2020	0,803571	0,728047	0,855618	0,77562	19.06.2020	0,264437	0,240654	0,30914	0,260869
17.12.2020	0,720627	0,753035	0,788565	0,732905	16.09.2020	0,707867	0,741056	0,782499	0,80371	18.06.2020	0,258202	0,241427	0,312014	0,265502
16.12.2020	0,577361	0,643423	0,621892	0,7211765	15.09.2020	0,66973	0,665448	0,728378	0,70771	17.06.2020	0,270962	0,25392	0,308342	0,259276
15.12.2020	0,617963	0,563307	0,660208	0,5779729	14.09.2020	0,816911	0,747625	0,653981	0,669629	16.06.2020	0,252692	0,246707	0,307863	0,272018
14.12.2020	0,638119	0,576831	0,698843	0,6185158	13.09.2020	0,9	0,838045	0,868549	0,818045	15.06.2020	0,241091	0,228933	0,29557	0,253774
13.12.2020	0,631013	0,589583	0,694213	0,6384977	12.09.2020	0,786895	0,9	0,838855	0,9	14.06.2020	0,243556	0,220431	0,288864	0,24219

4. TAHMİN MODELLERİNİN PERFORMANS DEĞERLENDİRİLMESİ

Bu çalışmada performans göstergeleri olarak ME, MPE, MAE, MSE, RMSE, MAPE ölçütlerinden yararlanılmıştır.

ME, Ortalama hata makine öğrenmesinde öngörülen modelin tahmin değerleri ile gerçekleşen değerler arasındaki ortalama hata hesaplanmasıdır. Sonucunda oluşan hata bir ölçümde belirsizliğe veya tahmin ile gerçekleşen arasındaki farklardır. Denklem (1) gösterilmiştir.

$$ME = \frac{1}{n} \sum_{j=1}^n e_j \quad (1)$$

MPE, ortalama yüzde hatadır. Tahminleyici modellerin karşılaştırmasında daha çok kullanılmaktadır. Hesaplanırken tahmin hataların mutlak değerlerinin aksine gerçek değerler kullanılmaktadır. Denklem (2)'de verilmiştir.

$$MPE = \frac{100}{n} \sum_{j=1}^n \frac{e_j}{A_j} \quad (2)$$

MAE, Ortalama mutlak hata sürekli olan iki değişken arasındaki farkın ölçüsüdür. Gerçek olan her değer ile en iyi veriye uyan çizgi arasındaki ortalama dikey mesafedir. Aynı zamanda da verilerin her noktası ile en iyi uyum sağlayan çizginin yatay ortalama mesafesidir. Kolay yorumlanabilmektedir. Bu yüzden regresyon ve zaman serisi probleminde kullanılabilir. Denklem eşitliği (3)'de gösterilmiştir.

$$MAE = \frac{1}{n} \sum_{j=1}^n |e_j| \quad (3)$$

MSE, Ortalama kare hata regresyon eğrisi için noktaya ne kadar yakın olduğu hakkında bilgi vermektedir. Sıfıra yakın olan durumların iyi performans göstermektedir. Denklem eşitliği (4)'de gösterilmiştir.

$$MSE = \frac{1}{n} e_j^2 \quad (4)$$

RMSE kök ortalama kare hatası, tahmin hataların standart sapmasını ifade etmektedir. Regresyon hattındaki veri noktalarına uzaklıklarının ölçmektedirler. Modeldeki değerlerin sıfır olması hiç hata yapılmadığı anlamında gelmektedir. Büyük olan hatalar daha fazla cezalandırılmaktadır. Denklem eşitlikleri (5) ve (6)'da verilmiştir.

$$RMSE = \sqrt{\frac{\sum_{j=1}^n e_j^2}{n}}$$

(5)

$$RMSE = \sqrt{MSE}$$

(6)

MAPE Ortalama mutlak yüzde hata, regresyon ve zaman serilerinde tahminlerin doğruluğunu hesaplamak için sıkça kullanılmaktadır. Gerçek değerlerde sıfır içeren bir rakam olmamalıdır (veribilimcisi,2021).

$$MAPE = \frac{100}{n} \sum_j \frac{|e_j|}{|A_j|}$$

(7)

4.1. Yapay Sinir Ağları İle Tahmin

Bu çalışmada seçilen üç adet kripto para için yapay sinir ağları ile fiyat modellemesi yapılmıştır. YSA modellemesi üzerine çalışmak amacıyla veriler Matlab programına girilmiştir. Yapay sinir ağları kullanılırken ne kadar çok veri işlenirse o kadar doğru sonuçlar elde edilmektedir. Bu sebeple veriler günlük olarak alınmıştır.

Çalışma kapsamında kullanılan yapay sinir ağları modeli, ileri beslemeli YSA sınıfındadır. Bu ağın seçilmesinin nedeni ekonometrik verilerin modellenmesi ve öngörü çalışmalarının yapılmasında en çok tercih edilen model olması ve hem doğrusal hem de doğrusal olmayan modellerde elde ettiği tahmin başarısıdır.

Normalize edilen veriler, 01.01.2020-31.12.2020 tarihleri arasında girdi verileri olarak (açılış, en yüksek ve en düşük değerler) ve çıktı verileri olarak (yani kapanış değerleri) ağı eğitmek amacıyla programa aktarılmıştır. Ağ eğitimi için Gradient Descent öğrenme algoritması (traingdx) kullanılmıştır. Performans

ölçümü için ise hata kareleri ortalaması (MSE) seçilmiştir. Epoch sayısı 1000 olarak tercih edilmiştir. Epoch sayısı; tüm veri setinin kaç kez eğitileceğini göstermektedir. Bu değerin yüksek olması öğrenme süresini uzatsa da doğruluğu arttırmaktadır.

Elde edilen değerlerin mimari grafiği aşağıdaki gibi oluşturulmuştur. Her bir kripto para birimi için aynı işlemler gerçekleştirilmiştir.

Yapay sinir ağlarını uygulamak amacıyla kullanılan Matlab programını daha ayrıntılı incelemek adına adım adım yapılan işlemler listelenmiştir.

- İlk adımda veri kümesi “Import Data” sekmesinden programda açılır.
- Girdi değişkeni olarak tanımladığımız ve 2020 senesini oluşturan 365 adet veri (kripto para birimlerinin açılış, en yüksek ve en düşük değerleri) programa girdi fonksiyonu içinde aktarılmıştır.
- Sonrasında ise 2020 senesinin kapanış değerleri, çıktı değişkeni olarak çıktı fonksiyonu içinde programa tanımlanmıştır.
- Test kümesi içerisine ise 01.01.2021-07.05.2021 tarih aralığındaki açılış, en yüksek, en düşük değerleri tanımlanmıştır. Bu aralıktaki kapanış değerleri programa gösterilmemiştir. Programın eğitiminden sonra oluşturduğu tahmin değerlerinin gerçeğe ne kadar yakın olduğu test edilmek istenmiştir.

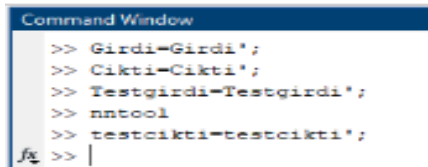
Girdi=Girdi’;

Cikti=Cikti’;

Testgirdi=Testgirdi’;

Kodları Matlab’a girilerek girdi, çıktı ve test değerlerinin transpozesi alınır.

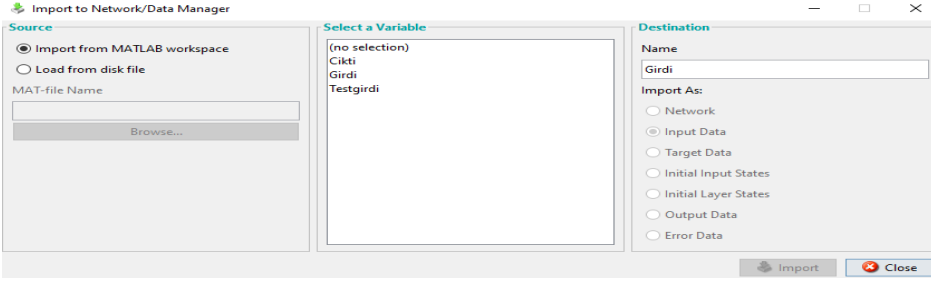
- Daha sonra nntool koduyla nntool aracı çağırılır.



```
Command Window
>> Girdi=Girdi';
>> Cikti=Cikti';
>> Testgirdi=Testgirdi';
>> nntool
>> testcikti=testcikti';
>> |
```

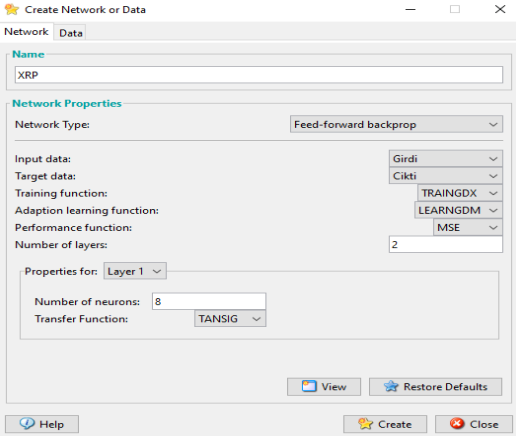
Şekil 2. Matlab command window ekranı

- Açılan nntool penceresinden Select a Variable sekmesinden girdi ve test değerlerimizi Input data olarak tanımlıyoruz. Çıktı değerlerimizi ise Target Data olarak belirliyoruz.




Şekil 3. Matlab data manager

- Yeni bir sinir ağı oluşturmak amacıyla New sekmesine tıklıyoruz. Açılan pencereden Input data olarak Girdi, Target data olarak ise Cikti adlı veri kümelerimizi giriyoruz. Eğitim fonksiyonu olarak TRAINGDX fonksiyonunu tercih ediyoruz. Deneme yanılmalar sonucunda en ideal nöron sayısını 8 olarak belirliyoruz. Create tuşuna basarak sinir ağını oluşturma işlemini sonlandırmış oluyoruz.



Şekil 4. Create network penceresi

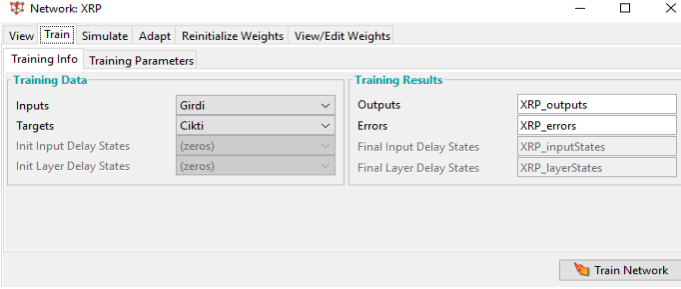
- Nntool arayüzünden yeni oluşturulan yapay sinir ağı incelenebilir.



Şekil 5.Yapay Sinir Ağı görünümü

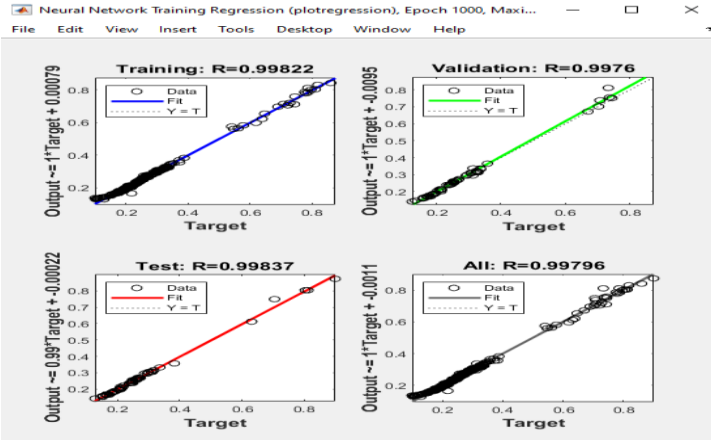
- Aynı alanda Train sekmesine tıklanarak Inputs kısmına girdi değerleri, Targets kısmına çıktı değerlerimizin olduğu veri kümesi aktarılır. Training Parameters bölümünden ise tekrar sayısı 500 olarak belirlenir. Bu sayının yüksek olması ağın iyi

öğrenmesi açısından önemlidir. Bu adımda son olarak Train Network tuşuna basılır ve ağ eğitimi başlatılır.

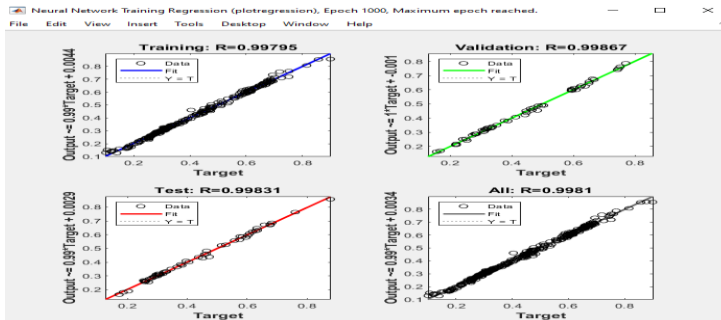


Şekil 6. Network penceresi

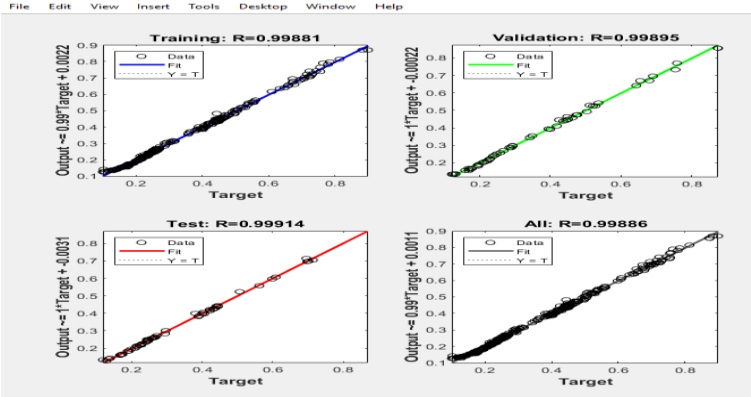
- Açılan pencerede regresyon analizi sonuçları görülebilir ve ağın verilerin doğruluk oranını incelenir.



Şekil 7. XRP için oluşturulan regresyon grafiği

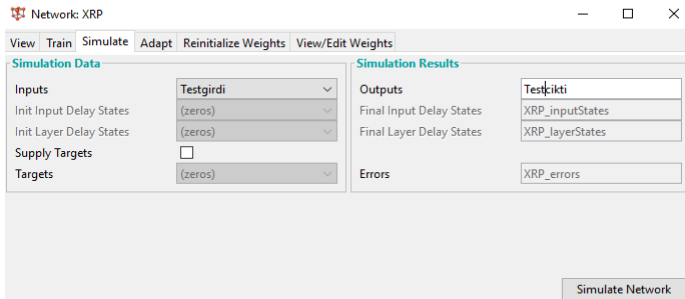


Şekil 8. BNB için oluşturulan regresyon grafiği




Şekil 9. ETH için oluşturulan regresyon grafiği

- Simulate sekmesine gidilerek Inputs değerleri olarak test değerleri veri kümesi aktarılır ve Simulate Network tuşuna basılır ve adımla yapay sinir ağı girilen test değerleri için tahmin değerleri üretir.



Şekil 10. Network XRP


- Ağın ürettiği tahmin sonuçlarına nntool arayüzünden ulaşılabilir.



Şekil 11. XRP için üretilen tahmin değerleri


Ağın eğitimi tamamlandıktan sonra ağ tahmini için test girdileri programa aktarılır. Test girdileri için 01.01.2021-07.05.2021 tarih aralığı seçilmiştir. Programa gerçek çıktı değerleri gösterilmez ve bunu tahmin etmesi beklenir.

Aşağıda yer alan şekilde XRP, BNB, ETH kripto para birimleri için yapay sinir ağlarının gerçekleştirdiği tahmini sonuçlar ve bu sonuçlarla gerçek değerlerin kıyaslandığı grafikler yer almaktadır.



Şekil 12. XRP için yapay sinir ağları tahmin sonuçları

Ripple (XRP) için 127 adet veri setinin ürettiği fiili çıktı değeri yukarıdaki şekilde görüldüğü gibidir. Değerler 1.01.2021-1.05.2021 tarihleri arasındaki günlük değerlerdir.



Şekil 13. XRP için gerçek değerler ve tahmin değerleri kıyaslaması

XRP kripto para biriminin ürettiği fiili sonuçlar ve 127 adet veri kümesinin gerçek çıktı değerlerinin kıyaslaması yukarıdaki grafikte verildiği gibi sonuçlanmıştır. Şekilde de gösterildiği gibi hata payları oldukça düşüktür.

Tablo 4. XRP, Matlab performans ölçütü


XRP					
ME	MPE	MAE	MSE	RMSE	MAPE
0,005082	3,112309	0,02408	0,003331	0,057717	8,760991

XRP değer tahmini için kullanılan YSA modelinin, performans ölçütü amacıyla belirlenen hata değerleri Tablo 4’de verildiği gibi sonuçlanmıştır. Modelin performansının daha iyi anlaşılabilmesi için bu tablo oluşturulmuştur.



Şekil 14. BNB için yapay sinir ağları tahmin sonuçları

Binance (BNB) için 127 adet veri setinin ürettiği fiili çıktı değeri yukarıdaki şekilde görüldüğü gibidir. Değerler 1.01.2021-1.05.2021 tarihleri arasındaki günlük değerlerdir.




Şekil 15. BNB için gerçek değerler ve tahmin değerleri kıyaslaması

BNB kripto para biriminin ürettiği fiili sonuçlar ve 127 adet veri kümesinin gerçek çıktı değerlerinin kıyaslaması yukarıdaki grafikte verildiği gibi sonuçlanmıştır. Şekilde de gösterildiği gibi hata payları oldukça düşüktür.

Tablo 5: BNB, Matlab performans ölçütü


BNB					
ME	MPE	MAE	MSE	RMSE	MAPE
0,002132	-2,24472	0,018956	0,000587	0,02422	8,500295

BNB değer tahmini için kullanılan YSA modelinin, performans ölçütü amacıyla belirlenen hata değerleri Tablo 5’te verildiği gibidir. Modelin performansının daha iyi anlaşılabilmesi için bu tablo oluşturulmuştur.



Şekil 16: ETH için yapay sinir ağları tahmin sonuçları

Ethereum (ETH) için 127 adet veri setinin ürettiği fiili çıktı değeri yukarıdaki şekilde görüldüğü gibidir. Değerler 1.01.2021-1.05.2021 tarihleri arasındaki günlük değerlerdir.



Şekil 17: ETH için gerçek değerler ve tahmin değerleri kıyaslaması

ETH kripto para biriminin ürettiği fiili sonuçlar ve 127 adet veri kümesinin gerçek çıktı değerlerinin kıyaslaması yukarıdaki grafikte verildiği gibi sonuçlanmıştır. Şekilde de gösterildiği gibi hata payları oldukça düşüktür.

Tablo 6: ETH, Matlab performans ölçütü

ETH					
ME	MPE	MAE	MSE	RMSE	MAPE
0,011844	3,172532	0,015267	0,018097	0,134524	4,376523

ETH değer tahmini için kullanılan YSA modelinin, performans ölçütü amacıyla belirlenen hata değerleri Tablo 6'de verildiği gibidir. Modelin performansının daha iyi anlaşılabilmesi için bu tablo oluşturulmuştur.

İncelenen üç kripto para birimi için de yapay sinir ağları modelinin gerçeğe yakın değerler ürettiği söylenilebilir. Her ne kadar gerçek değerlerle sapmalar gerçekleşse de genel anlamıyla yükselmesi ya da düşmesi gereken yerler tahmin edilebilmiştir.

Bundan sonraki bölümde ise LSTM ile bu kriptolar için tahmin modeli oluşturulacak ve performans ölçümleri yapılacaktır.

4.2. LSTM Modeli ile Tahmin

LSTM, derin öğrenme sınıfının üyesidir. LSTM sayesinde finans sektöründe risk ve zarar ile ilgili durumlara yönelik model oluşturulabilir. Bu metot ile eski dönemlere ait zaman serileriyle tahmin işlemi yapılabilir. Temel amaç modellemede geçmiş veriler eğitimi yapılarak ertesi günler için finansal verileri tahmin edebilmektir. Model iyi yapılandırılmasıyla fiyatlandırma başarılı olabilmektedir(Akkurt,2005).

Modelimizde keras kütüphanesini kullanarak geliştirilmiştir. Bu modelde kripto paraların 2020 yılındaki fiyat zaman serileri girdi olarak değerlendirilmiştir. 365 günlük girdi değerleri NumPy ile tek boyutlu duruma getirilmiştir. İlgili veri setleri için Yahoo sayfasından ilgili kriptonun geçmiş verileri çekilmektedir. Çalışmada kapanış fiyatları esas alınarak fiyat tahmini yapılmıştır. LSTM tahmin modelinin adımları aşağıdaki gibidir:

Adım 0. Kütüphane ve zaman serisi ile ilgili veri setleri yüklenir.

Şekil 18: LSTM modeli için ilgili kütüphanelerin yüklenmesi

```
# kütüphaneyi getir
import math
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from keras.models import Sequential
from keras.layers import Dense, LSTM
import pandas_datareader as web
plt.style.use('fivethirtyeight')
```

Şekil 19: LSTM modeli için verilerin sistemden çekilmesi

```
[ ] #fiyatları al
df = web.DataReader('BNB-USD', data_source='yahoo',start='2020-01-01',end='2021-05-07')#tarih değer aralıkları
df.shape
(490, 6)
```

Adım 1: Veri setindeki kapanış fiyatlarına göre veri düzenlenmektedir.

Şekil 20: Kapanış fiyatları ile ilgili veri seti düzenlenmesi

```
[ ] #kapanış fiyatları ile ilgili yeni data oluştur.  
    data = df.filter(['Close'])  
  
[ ] # datayı numpy veri setine dönüştür  
    dataset = data.values
```

Adım 2: Veri setinde 2021 yılı test için ayrılır, geri kalan kısım eğitim seti olarak belirlenmektedir.

```
[ ] #eğitilecek satırları al  
  
    training_data_len = 365
```

Şekil 21: 2020 yılına ait verilerin eğitilmesi

Adım 3: Eğitim verilerini kullanarak ilgili model eğitilmektedir.

Şekil 22: Eğitilecek olan veri setinin düzenlenmesi

```
[ ] #eğitilecek satırları x ve y koordinatlarına ayır  
    x_train = []  
    y_train = []  
  
[ ] for i in range(60, len(train_data)):  
    x_train.append(train_data[i-60:i, 0])  
    y_train.append(train_data[i, 0])  
    # if i<=61:  
    #     print(x_train)  
    #     print(y_train)  
    #     print()  
  
[ ] #x_train ve y_train modellerini numpy serilerine çevir  
    x_train, y_train = np.array(x_train), np.array(y_train)  
  
[ ] #datayı yeniden şekillendir.  
    x_train = np.reshape(x_train,(x_train.shape[0],x_train.shape[1],1))
```

Adım 4: LSTM modeli kurulur.

Şekil 23:Derin öğrenme algoritmasının kurulması

```
#LSTM modelinin yapılması
model =Sequential()
model.add(LSTM(50, return_sequences=True, input_shape =(x_train.shape[1],1)))
model.add(LSTM(50, return_sequences=False))
model.add(Dense(25))
model.add(Dense(1))

#fiyat modellemesini derleme
model.compile(optimizer='Adam', loss='mean_squared_error')

#modeli eđit
model.fit(x_train,y_train, batch_size=1,epochs=1)

305/305 [=====] - 10s 23ms/step - loss: 8.1679e-05
<tensorflow.python.keras.callbacks.History at 0x7f11e2b2650>
```

Adım 5. Test verileri eğitilen model üzerinden tahmin edilir.

Şekil 24: Tahmin edilecek verilerin oluşturulması

```
#tahmin edilen fiyatları al
predictions = model.predict(x_test)

predictions = scaler.inverse_transform(predictions)

[ ] rmse = np.sqrt(np.mean(predictions - y_test)**2)

[ ] #veriyi taşı
train = data[:training_data_len]
valid = data[training_data_len:]
valid['Tahminler']= predictions
```

Adım6. Hata oranları ile ilgili sonuçlar ekrana yazdırılmaktadır.

Aşağıda yer alan şekilde XRP, BNB, ETH kripto para birimleri için LSTM gerçekleştirdiği tahmini sonuçlar ve bu sonuçlarla gerçek değerlerin kıyaslandığı grafikler yer almaktadır. Verileri görselleştirebilmek için Şekil 4.16'daki kodlamalardan yararlanılmıştır.


Şekil 25: Veri görselleştirme algoritmaları

```
#veriyi görselleştir
plt.figure(figsize=(16,8))
plt.title('model')
plt.xlabel('Tarih', fontsize=18)
plt.ylabel('Kapanış Fiyatları', fontsize=18)
plt.plot(train['Close'])
plt.plot(valid[['Close','Tahminler']])
plt.legend(['Eđitilen Alan','Deđer','Tahminler'],loc='lower right')

plt.show()
```


XRP kripto parası için oluşturulan derin öğrenme algoritmasındaki çıktı sonuçları ile ilgili grafik Şekil 25’de gösterilmektedir. 2020 yılındaki veri seti eğitim için kullanıldıktan sonra gerçek ve tahmin edilen veriler arasındaki performans ölçütleri Tablo 7’ da yer verilmiştir.

Şekil 26: XRP gerçek değerler ve tahmin değerleri kıyaslaması




Tablo 7: XRP, LSTM performans ölçütü

XRP					
ME	MPE	MAE	MSE	RMSE	MAPE
-0,0142	-7,12693	0,05337	0,02521	0,158777	15,54828

XRP değer tahmini için kullanılan LSTM modelinin, performans ölçütü amacıyla belirlenen hata değerleri Tablo 7’da verildiği gibidir. Modelin performansının daha iyi anlaşılabilmesi için bu tablo oluşturulmuştur.

Şekil 27: BNB gerçek değerler ve tahmin değerleri kıyaslaması

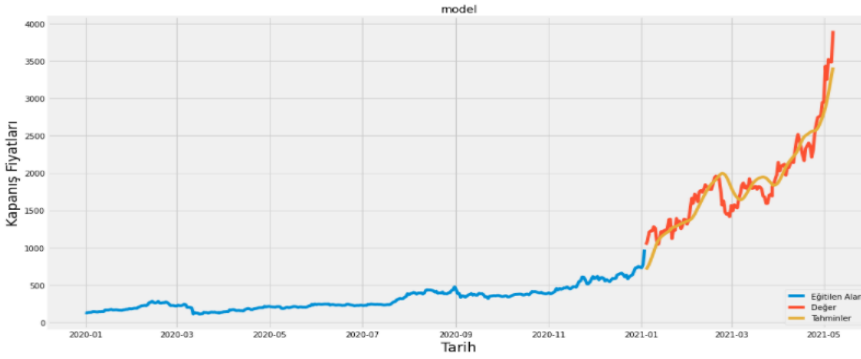


Tablo 8: BNB, LSTM performans ölçütü

BNB					
ME	MPE	MAE	MSE	RMSE	MAPE
-0,01365	-2,59889	0,043655	0,023302	0,15265	11,32059

BNB değer tahmini için kullanılan LSTM modelinin, performans ölçütü amacıyla belirlenen hata değerleri Tablo 8’de verildiği gibi sonuçlanmıştır. Modelin performansının daha iyi anlaşılabilmesi için bu tablo oluşturulmuştur.

Şekil 28: ETH gerçek değerler ve tahmin değerleri kıyaslaması



Tablo 9: ETH, LSTM performans ölçütü

ETH					
ME	MPE	MAE	MSE	RMSE	MAPE
-0,10813	-39,4492	0,109332	1,461499	1,208925	40,045

ETH değer tahmini için kullanılan LSTM modelinin, performans ölçütü amacıyla belirlenen hata değerleri Tablo 9’de verildiği gibi sonuçlanmıştır. Modelin performansının daha iyi anlaşılabilmesi için bu tablo oluşturulmuştur.

5. BULGULAR

Tablo 10: Matlab ve LSTM Kıyaslama Tablosu

KIYASLAMA İÇİN GENEL TABLO

		ME	MPE	MAE	MSE	RMSE	MAPE
MATLAB	BNB	0,002132	-2,24472	0,018956	0,000587	0,02422	8,500295
	XRP	0,005082	3,112309	0,02408	0,003331	0,057717	8,760991
	ETH	0,011844	3,172532	0,015267	0,018097	0,134524	4,376523
LSTM	BNB	-0,01365	-2,59889	0,043655	0,023302	0,15265	11,32059
	XRP	-0,0142	-7,12693	0,05337	0,02521	0,158777	15,54828
	ETH	-0,10813	-39,4492	0,109332	1,461499	1,208925	40,045

Toplamda 127 günün kapamış verileri LSTM ve YSA modellerinin performans karşılaştırması için Tablo 10’da verildiği şekilde derlenmiştir.

Bu çalışmada doğruluk ölçütü olarak ME, MPE, MAE, MSE, RMSE ve MAPE esas alınmıştır. Kullanılan bu ölçütler aslında hata katsayıları olduğu için düşük sonuç vermeleri sistem performansı ile ters orantılı olarak işlemektedir.

Literatürde, MAPE değerlerinin performans kıyaslaması için gerçeği tam olarak yansıtmadığı, MSE ve RMSE ölçütlerinin kriter olarak kullanılmasının daha doğru sonuçlar doğuracağı tavsiye edilmektedir. (Arabacı,2007:40). Bu araştırmada da her bir kripto değeri için MSE ve RMSE hata ölçütleri kullanılarak en iyi sonuç veren metot incelenmiştir.

BNB için verilen MSE ve RMSE değerlerinin YSA sonucu LSTM sonucundan daha düşük bir orana sahiptir. Bu sonuç, BNB para birimi için YSA ile tahmin yapmayı daha uygun kılmaktadır.

Tabloda XRP sonuçları incelendiğinde ise, yine MSE ve RMSE değerlerinin YSA sonuçlarının LSTM sonuçlarından daha düşük olduğu açıkça görülmektedir. XRP para birimi için tablodaki sonuçlara dayanarak, YSA sonuçları anlamlı değerler üretmiştir denilebilir.

LSTM, ETH kripto para birimi için çok büyük hata oranları üretmiştir. ETH’de yine her iki ölçüt de YSA için daha az hata payları ortaya çıkarmıştır. Bu sonuçtan yola çıkarak, LSTM’nin fiyat dalgalanmaları sık ve yüksek olan kripto para birimlerinde kullanılmasının uygun olmadığı sonucuna varılabilir.

Bu sonuçlar incelendiğinde Matlab programı ile yapılan YSA modeli seçilen kripto paralar için çok düşük hata payları çıkarmıştır. Özellikle XRP ve BNB için bu metodu kullanmak daha sağlıklı olabilir. ETH için çıkan hata payları diğer kripto paralarda meydana gelen hata payından daha fazladır.

6. SONUÇ

İlgili çalışmamızda yeni finansal teknoloji olarak kripto paralardan XRP, BNB ve ETH kripto paraları üzerinde inceleme yapılmıştır. Bu kripto paraların geliştirilmesi için altında yatan dağınık yapılar ve blok zinciri ile ilgili kavramlar hakkında bilgilere yer verilmiştir. Çalışmanın amacı yapay zekâ uygulamalarının fiyat tahmini için başarılarını değerlendirmektir.

Çalışmanın veri tabanı olarak Excel’de bulunan günlerin ve ilgili kripto paraların kapanış fiyatlarından oluşan veri setinden yararlanılmıştır. 2020 yılına ait veri setinin yardımıyla ağlar eğitilmiş ve bir sonraki yıl için tahmin edilmeye çalışılmıştır. İstatistik analizleri olan ME, MPE, MAE, MSE, RMSE ve MAPE hata metriklerinden faydalanarak sonuçların başarı incelenmiştir.

Tahminlemelerden çıkan sonuçlar performans ölçütleri ile kıyaslanıp incelendiğinde hata oranların göre en çok gerçek verilere yaklaşan matlabda oluşturmuş olduğumuz yapay sinir ağları olduğu saptanmıştır.

YAZARLARIN BEYANI

Katkı Oranı Beyanı: Yazarlar çalışmaya eşit oranda katkı sağlamıştır.

Destek ve Teşekkür Beyanı: Çalışmada herhangi bir kurum ya da kuruluştan destek alınmamıştır.

Çatışma Beyanı: Çalışmada herhangi bir potansiyel çıkar çatışması söz konusu değildir.

KAYNAKÇA

Akkurt, A.:Yapay Sinir Ağları Ve Türkiye Elektrik Tüketimi Tahmin Modeli ,Doctoral dissertation, Fen Bilimleri Enstitüsü,2005.

Arabacı, Ö.:Makroekonomik Zaman Serisi Analizi Ve Yapay Sinir Ağı Uygulamaları. Yayınlanmamış Doktora Tezi,Uludağ Üniversitesi,Sosyal Bilimler Enstitüsü,Ekonometri Anabilim Dalı,Bursa,2007

Aras, S.: “Kripto Para Fiyatlarının Klasik Ve Yapay Sınır Ağı Modelleri İle Tahmini”,Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 608-640, vol 10, 2019.

Ateş, B. A., “Kripto para birimleri, bitcoin ve muhasebesi.”, Çankırı Karatekin Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 7:1,2017, ss.349-366.

Atlan, F. , “Kripto para değerlerinin yapay zekâ teknikleri ile tahmini”, Yüksek Lisans Tezi, Burdur Mehmet Akif Ersoy Üniversitesi, Burdur, 2019

Ceylan, Mehmet Emin. Bitcoin ekonomisi: Kripto para Bitcoin'in finans sektörü içindeki yeri. MS thesis. Batman Üniversitesi Sosyal Bilimler Enstitüsü, 2019.

Coin Market Cap.(2021). Piyasa değerine göre, en iyi 100 kripto para birimleri, <https://www.coinmarketcap.com>, [İndirme Tarihi: 15.06.2021]

Dağlı, İ., “Kripto Paraların Dünya Ekonomisindeki Makroekonomik Boyutu Ve Türk Lirası Bazında Yatırım-Tasarruf Aracı Olarak Kripto Paralara Genel Bir Bakış “. Uygulamalı Ekonomi ve Sosyal Bilimler Dergisi , 2019,1,ss.40-49

Demirel, A. C., “Hazar A., Kripto Para Değerlerine Dayanılarak BİST 100 Endeks Hareketi Tahmininde Destek Vektör Makineleri Uygulaması”, Başkent Üniversitesi Ticari Bilimler Fakültesi Dergisi, 2021, Vol 5, ss.27-35.

Kaplanhan, F., “Kripto Paranın Türk Mevzuatı Açısından Değerlendirilmesi "Bitcoin Örneği"”, Vergi Sorunları Dergisi, 2017, 105-123.

Karakoyun, E. Ş., “Derin öğrenme ile zaman serilerinin gerçek zamanlı tahmini.” MS thesis., Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Konya ,2018.

Karahan, M., “Yapay Sınır Ağları Metodu İle İhracat Miktarlarının Tahmini: ARIMA ve YSA Metodunun Karşılaştırmalı Analizi.”, Ege Academic Review, 15:2, 2015

Nakamoto, S. (2008). Bitcoin: A Peer-to-Peer Electronic Cash System. <https://www.bitcoin.org>[İndirilme Tarihi:21.02.2021]

Özkul, F. U., & Baş, E. , “Dijital Çağın Teknolojisi Blokzincir ve Kripto Paralar: Ulusal Mevzuat ve Uluslararası Standartlar Çerçevesinde Mali Yönden Değerlendirme”. Muhasebe ve Denetime Bakış., 2020, ss.173-188

Şahin, E. E., Bağcı, B., “Kripto Para Fiyatlarının Tahmininde Gri Sistem Teorisi: Yöntemsel Karşılaştırma”, Anadolu Üniversitesi Sosyal Bilimler Dergisi, Vol 20, 2020, ss.219-232,

Temür, A.S. "İşletmelerin satış bütçelerinin oluşturulmasında arıma, lstm ve hibrit modellerin karşılaştırılması: üretim işletmesi örneği.", Volume 20 :5,2019,ss. 920–938

Ömruuzun, B., & Saldanlı, Ö. Ü. A., "Yapay Sinir Ağları İle Kripto Paraların Fiyat Modellemesi", Yüksek Lisans Tezi , İstanbul Üniversitesi, İstanbul,2019

<https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/>,[İndirilme Tarihi :11. Mayıs.2021]

"All Cryptocurrencies", Coin Market Cap, <https://coinmarketcap.com/all/views/all/> [20.03.2021].

Coin Market Cap, <https://coinmarketcap.com>: <https://coinmarketcap.com/charts/> ,[İndirilme Tarihi : 5 Mayıs 2021]

"What is IOTA", IOTA, <https://docs.iota.org/introduction>, [İndirilme Tarihi :13.04.2018].

"Smart payments made simple", Byteball, Completely new technology, <https://byteball.org> [İndirilme Tarihi :13.04.2018].